

Interdisciplinarno djelo široke primjene

(Brano Markić, *Sustavi potpore odlučivanju i poslovna inteligencija: podaci, modeli i algoritmi*, Napredak, Glavna podružnica Mostar, Mostar, 2014.)

Knjiga – udžbenik *Sustavi potpore odlučivanju i poslovna inteligencija: podaci, modeli i algoritmi* autora prof. dr. Brane Markića, nastavnika na Ekonomskome fakultetu Sveučilišta u Mostaru, pisana je za studente ekonomskih, ali i drugih fakulteta, kao udžbenik za područja tzv. sustava za podršku odlučivanju (engl. *Decision Support Systems* – DSS), poslovne inteligencije (BI), otkrivanje znanja u podacima za poslovne funkcije menadžmenta, financija i marketinga.

Knjiga je interdisciplinarna jer priroda DSS i BI sustava povezuje više znanstvenih disciplina. Naime DSS/BI sustavi primjenjivi su u svim poslovnim funkcijama: marketingu, financijama, menadžmentu, upravljanju ljudskim resursima, računovodstvu. Posebna kvaliteta knjige je u tome što je autor detaljno objasnio temeljne komponente DSS sustava kroz koncepte DBMS-a i matematičko-statističko-simulacijskih modela i tehnika. Također, posebnu kvalitetu knjizi daju primjeri pisani u programskome jeziku/statističkome softverskom alatu „R“, ali i u Excelu, Prologu i Visual Basicu.

Čitatelji se zato moraju prethodno upoznati s tim programskim jezicima i alatima kako bi mogli razumjeti primjere dane u knjizi. U tome kontekstu autor čitatelja upućuje na odgovarajuće izvore.

Knjiga sadrži pet poglavlja uz predgovor, popis pojmova i literature. Poglavlja su strukturirana na sljedeći način: „Informacijski sustavi i poslovno odlučivanje“, „Podaci kao komponenta sustava potpore odlučivanju“, „Modeli kao komponenta sustava potpore odlučivanju“, „Sustavi potpore odlučivanju i poslovna inteligencija“, „Statistički modeli u sustavima za potporu odlučivanju“.

Prvo poglavlje obrađuje poslovno odlučivanje i informacijske sustave (IS) na način da je dana taksonomija informacijskih sustava s obzirom na ulogu u donošenju odluka. Analiziraju se glavna obilježja transakcijskih IS-a, upravljačkih IS-a, DSS-a, ekspertnih sustava i inteligentnih informacijskih sustava. Autor nastoji „demistificirati“ ekspertne sustave te se zato fokusira na logičko programiranje i daje primjer

ekspertnoga sustava pisanoga u jeziku Prolog.

Drugo poglavlje obrađuje podatke. U fokusu autora je informatički pogled na podatke, informacije i znanje u okviru koncepta DSS-a. Prikazan je model podataka i potrebna znanja za logičko oblikovanje baza podataka. Autor je uložio napor kako bi čitateljima objasnio podatke koji su polazna točka za poslovnu inteligenciju i otkrivanje znanja pomoću modela *data mininga*. Osim informatičkoga pogleda na strukturiranje podataka, autor analizira i vrste podataka te statističke metode analize prihvatljive za pojedine vrste podataka.

Treće poglavlje nosi naslov „Modeli u sustavima potpore odlučivanju i poslovnoj inteligenciji“. Autor se fokusira na modele koji pomažu u odlučivanju za strukturirane probleme odlučivanja kao što je linearno programiranje, ali i modele za odlučivanje u uvjetima rizika i neizvjesnosti. Autor se nakon teorijske analize služi primjerima i na jednostavan i koncizan način čitateljima prezentira „modele odlučivanja u uvjetima rizika i neizvjesnosti kao komponente sustava za potporu odlučivanju“. U ovome poglavlju autor na jednostavan način prikazuje „razvojni proces sustava za potporu odlučivanju temeljenih na tabličnim kalkulatorima koji dekomponira u šest koraka:

1. Kratak prikaz aplikacije sustava za potporu odlučivanju
2. Radni listovi
3. Korisnički interface
4. Procedure
5. Testiranje rješenja
6. Implementacija“.

Prikaz aplikacije kratak je opis ulaznih podataka, modela i kalkulacija, izlaza te korištenja. Prikazana je cijela aplikacija kako bi korisnik razumio tijek događaja od korisničkoga unosa podataka, kalkulacija u modelu do izlazne informacije. Nakon teorijskoga uvoda autor ponovno prikazuje implementaciju svih koraka i čitatelju otvara mogućnost „brzog“ usvajanja teorijskih znanja razvoja DSS-a, ali istodobno i mogućnost da samostalno razvija DSS-aplikacije.

Autor se služi R jezikom u objašnjavanju primjera, što čitatelju otvara mogućnost samostalnoga „eksperimentiranja“ s naredbama R jezika u implementaciji modela.

Četvrto poglavlje ima naslov „Sustavi potpore odlučivanju i poslovna inteligencija“. Autor pravi distinkcije između pojmova „upravljanje znanjem“, „poslovna inteligencija“, „skladište podataka“, „data mining“ i „sustavi potpore odlučivanju“ i pojedinačno ih obrazlaže. Naglašava da su poteškoće razvoja i primjene rješenja poslovne inteligencije mnogobrojne. Prvo, obuka za primjenu alata poslovne inteligencije je skupa,

alati poslovne inteligencije su složeni za uporabu, potrebe za poslovnim inteligencijom teško se mogu brzo identifikirati, rješenja poslovne inteligencije potrebno je prilagoditi korisniku (*customize*), ne prepoznaju se koristi od poslovne inteligencije u ekonomskome smislu (brzina povrata uloženo).

Autor obrađuje i algoritme rudarenja podacima (*data mining algorithms*) kao dio širega procesa otkrivanja znanja te naglašava da „izvršni informacijski sustavi, sustavi za potporu odlučivanju igraju ključnu ulogu u pretraživanju, pronalaženju i prikazivanju znanja, tj. transformaciji podataka u poslovnu inteligenciju“. To je dobro poznati DSS proces u kojemu se podatci prikupljaju (iz različitih izvora, zatim filtriraju, pročišćavaju, transformiraju, konsolidiraju i pune u skladišta podataka), analiziraju i transformiraju u informacije, a zatim dalje u znanje. U tome procesu uspostavlja se dobro poznati lanac vrijednosti informacija (*information value chain*) u kojem se podatci pohranjuju u transakcijske baze podataka i transferiraju u analitičke baze (multidimenzijske baze i skladišta podataka). Analitičke baze pohranjuju podatke u obliku koji je prihvatljiv za daljnja poboljšanja i analizu. Ti podatci tako završavaju kao informacije.

Autor također prezentira više algoritama *data mininga* od kojih se posebno mogu izdvojiti neuronske mreže i

genetički algoritmi s primjerima danim u R jeziku. Prikazao je detaljno neuronske mreže i tzv. algoritam *backpropagation* za „prilagođavanje težinskih faktora pomoću kojih neuronska mreža uči i prilagođava se sustavu“.

Četvrto poglavlje ima posebnu vrijednost jer integrira matematička, informatička i znanja iz poslovnoga odlučivanja.

Peto poglavlje posebno izdvaja statistiku, gdje autor naglašava „da su statistički modeli, deskriptivna i inferencijalna statistika bitan dio sustava potpore odlučivanju“. Ovo poglavlje također sadrži veliki broj primjera i naredbi R jezika, pa se zato može promatrati i kao vodič za korištenje R jezika u statistici.

Na osnovi svega navedenog nedvojbeno je da se radi o knjizi koja na vrlo respektabilan način obrađuje problematiku DSS/BI sustava i aplikacija. Materijal može biti od koristi studentima dodiplomskih, poslijediplomskih i doktorskih studija. Knjiga može poslužiti i kao dobar vodič za ljude koji se bave izgradnjom DSS/BI sustava unutar kompanija, a posebno se preporučuje menadžerima različitih profila i razina koji u toj vrsti IT-podrske vide pomoć u poslovnome odlučivanju.

Nijaz Bajgorić

nijaz.bajgoric@efsa.unsa.ba